

30. コンクリート打設の自動管理におけるエッジ AI システムの利用

立命館大学
立命館大学
立命館大学

○ 福原 大祐
善本 哲夫
横山 隆明

1. はじめに

本研究は地場の中小建設業者支援を目的に、AIを活用するコンクリート打設の効率化・合理化の技術開発を展開するものである。新規就業者の確保が困難な現状において、現役世代への負担は増大している。このような背景から、建設/インフラDXが目指すデジタル技術の活用は、既存の人的資源が本来の業務で最大限のポテンシャルを発揮できるようにすることが重要である。

本研究が焦点を当てるコンクリート打設において、昨今の労働事情を踏まえれば直接作業以外の付随業務に人員を配分することは厳しい状況にある。この問題に対処するため、エッジコンピューティングを活用してリアルタイムでのデータ処理を行い、ICT技術¹⁾によって時間管理などの業務を自動化することで、限られた人的資源をより高付加価値な作業に集中させることが可能となる。

本研究は、物体検出モデルと文字認識モデルを組み合わせた画像処理技術を用いて、エッジAIシステムを活用したコンクリート打設の自動管理システムを提案する。提案したエッジAIシステムを活用することで、コンクリート打設のDX化推進と建設現場におけるリアルタイムのデータ処理による省人化および作業効率の向上が可能となる。

またDXの文脈において建設現場が抱える大きな課題の一つが安定した通信環境の確保である。特に山間部や河川では通信環境が不安定である場合も多く、画像・動画データを使った多様な建設プロセス革新の取り組みを導入できない場面に遭遇することがある。特に、クラウドベースのシステムでは通信環境が解決の難しい制約条件の一つになり得る。

この問題に対処するため、本研究ではエッジコンピューティングの活用を検討した。具体的には、①通信環境の良し悪しに左右されないオンプレミスのシステムであること、②過酷な現場環境において高い頑健性/耐環境性および保守メンテナンス性を確保することを基軸として目指している。特に中小建設業者にとってメンテナンスの容易性は極めて重要な論点になる。以上の考え方をもとに、汎用パソコンによるシステム構築とともに、本研

究では製造業や上下水道管理で実績のある産業用コンピュータ活用の検証を進めている。これにより、コンクリート打設の自動管理を実現し、建設現場でのリアルタイムデータ処理による省人化と作業効率の向上が期待される。これらの先進技術の組み合わせによって、建設業界、特にコンクリート打設作業における多くの課題に対する有望な解決策を提供することが、本研究の主要な目的である。

2. 構築したエッジAIシステムについて

本研究では中小建設業者の現場施工者によるトラックミキサーの管理を支援する目的で、深層学習モデルとエッジAIシステムを組み合わせた自動管理システムを構築した。さらに、このシステムは通信環境が不安定な場所でも運用可能なエッジAIシステムとして設計されているため、山間部や河川など通信が困難な環境でも活用できる。通信環境を用意することが困難な環境でもより簡易に、中小建設業者の現場施工者はリアルタイムでのトラックミキサーの自動管理を実現することが可能となる。

2.1 エッジAIシステムについて

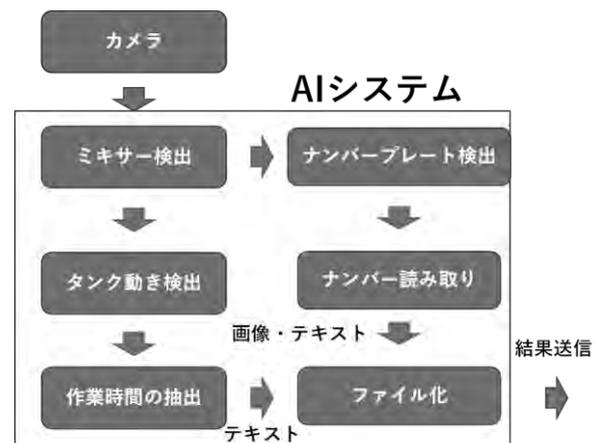


図-1 エッジAIシステムの処理フロー図

図1は本研究で構築したエッジAIシステムのフロー図である。まず、カメラによって検出対象のトラックミキサーを映すことでデータを取り込む。

本研究では、様々な状況に対応するために AI システムに柔軟性を持つように、様々な画角から撮影した画像を分析することを検討した。しかし、カメラを 1 台に収めるためにトラックミキサーを斜めから撮影し、ナンバープレートとタンク部分の回転が同時に見える画角から撮影した。AI システムを処理するハードウェアの性能が十分であれば、複数のカメラで取り込んだ画像データよりトラックミキサーとタンク、ナンバープレートを物体検出で画像を抽出する。トラックミキサーのタンクの回転向きでコンクリートを排出しているかを識別できるため、本研究では検出したタンクの動きを検出してコンクリート打設開始と終了時刻を判別した。ただし、排出量の微調整によってタンクの動きは稼働と停止を繰り返すことがあるので、トラックミキサー車が作業を終了して移動を開始し始めた最後の動きから終了時刻を最終決定するものとした。

また、抽出したナンバープレートを文字認識することで、トラックミキサーの個体識別を行った。計算負荷が高い処理のため複数回の結果が一致することで個体識別を完了して、同じトラックミキサー車のナンバープレートの読み取り処理を実行しないこととした。

最後に、判別した打設開始時刻、打設終了時刻のテキストデータ、ナンバープレートから文字認識したテキストデータ、読み取りに失敗した場合のためのナンバープレートの画像データを 1 ファイルにまとめて保存するものとした。このシステム構成では、外部の通信環境が劣悪であっても同一ネットワーク環境が構築されていれば運用が可能である。

2.2 深層学習モデルについて

深層学習は、多層のニューラルネットワークを用いて高度な特徴を自動で学習することが可能である。本研究では物体検出をする際に、必要十分な精度で高速な物体検出が可能で YOLO (You Only Look Once) モデル²⁾を使用した。YOLO モデルは、一度の推論で画像内の複数の物体を検出するため、リアルタイム処理が可能で深層学習モデルである。この YOLO モデルは初期のモデルは、画像をグリッド状に分割してから分析するため、小さな物体の検出が苦手であった。現在では、YOLO モデルは複数の改良モデルが考案され、検出精度の向上、小物体検出の改善、計算効率の最適化などが行われている。本研究のエッジ AI システムでは、この YOLO モデルを使用して撮影した画面内から、トラックミキサー、ナンバープレート、タンク部分の物体検出を行ってその部分の画像を抽出している。

物体の動きをとらえるため、画像間のピクセルの動きである optical flow を計算する工程を加えた。

従来の optical flow を求める深層学習モデルでは、ネットワーク階層を増加させた場合に、増加させたネットワーク部分への入力画像の解像度が低くなってしまい、ネットワーク構造の問題で繰り返しの分析回数に上限があるため精度向上に課題があった。RAFT (Recurrent all pairs field transforms for optical flow) モデル³⁾では、再帰型ニューラルネットワークを用いることで従来の optical flow を求める深層学習モデルよりも、高解像度の入力画像データをより多くのネットワーク部分で繰り返しの分析を可能することで精度を高めているモデルである。

深層学習モデルであるこの RAFT モデルを用いて optical flow を算出すると計算にかかる負荷は大きいものの、従来の Farneback 法よりも高精度に物体の動きをとらえることが可能となった。

2.3 使用ハードウェア

表-1 エッジ AI システム実行環境

	OS	CPU	GPU
ノートPC機	Windows11	Ryzen 7 4700U	Radeon Graphics
デスクトップ機	Windows11	Ryzen 7 3800X	GeForce RTX 4070
産業用コンピュータのサーバー機	MIRACLE LINUX 8 Asianux Inside	Xeon Silver 4209T	GeForce RTX 4070



図-2 産業用コンピュータサーバー機 (FS20000R model100)

表 1 に、本研究で検証に使用したエッジ AI システムの実行環境を示す。図 2 の産業用コンピュータのサーバー機は、東芝インフラシステムズ株式会社製 FS20000R model100 の評価機を用いて検証を行った。また、深層学習モデルを処理する際に GPU を使うと高速化できるため、デスクトップ機とサーバー機は同一の GPU を組み込んで検証した。各検証機でプログラミング言語 Python を使って計測した。

ノート PC 機は携帯性が高く、現場での即時解析が可能であり、デスクトップ機は高い計算能力を持ち、大量のデータを高速に処理できる。産業用コンピュータのサーバー機は、ノート PC 機とデスクトップ機に対して高い頑健性、耐環境性および保守メンテナンス性が特徴である。24 時間の連続稼働を前提とした部品の採用及び設計で、製造業や上下水道管理などで24時間の連続稼働と信頼性が必要な用途で採用されている製品である。

2.4 訓練データの作成について

本研究で使用する YOLO モデルの転移学習のために、工事現場での学習データ用の動画撮影を複数日程の間実施した。工事現場での動画は、複数のカメラを使用して撮影され、その映像から特定のフレームが切り出されて訓練データとして整形した。

ナンバープレートの文字認識には、YOLO モデルを転移学習させるために、ナンバープレートが複数必要になるが画像データが不足するため、実際のナンバープレートのサイズと文字サイズの比率を測定し、文字の位置を含めそれに基づいて似た画像をランダムに自動生成し訓練データとして用いた。学習の際には、角度、距離、ぼやけぐあいのように工事現場で起こりうる状況を考慮したデータ拡張を行った。

モデルの学習はデスクトップ機で作成し、学習したモデルでその他の機器での検証を行った。学習後のテストデータでうまく推論できないデータを訓練データに含めて、その都度再学習を行った。

3. 結果と考察

3.1 エッジ AI システム実行時間の検証結果

表2にエッジ AI システムの実行速度の測定箇所を示す。大きく 3 区間に分けて計測を行い、トラックミキサーを画像から YOLO モデルで物体検出する処理を Truck、検出したナンバープレートの画像の傾きや台形補正の後、YOLO モデルで文字認識を行う処理を License、従来の Farneback 法による optical flow による CPU によるタンクの回転向きの検出をする処理を Tank と表記した。図3は、この3つの処理を動画100フレームで繰り返し実行し、100回平均したときの1フレームあたりの平均実行時間を比較した図である。サーバー機に関しては、比較のためCPUのみで実行したときの値とGPUを使って高速化したときの2通りを記載している。サーバー機のGPUを使って高速化した3つの処理の合計の実行時間は、サーバー機のCPUのみで実行したときの合計実行時間の0.58倍であった。GPUを使うことで特にTruckの処理がCPUのみを使う場合に対して0.16倍の実行時間となり、YOLOモデルの計算処理が高速化されていること

がわかる。GPUを使ったサーバー機の平均実行時間に対し、ノートPC機の平均実行時間は丁度同程度の実行時間であった。GPUを使ったサーバー機とノートPC機はその他にも、Licenseのみの処理時間と、TruckとTankの合計処理時間は同程度の実行時間となった。これは、サーバー機のGPU性能が高いのに対し、ノートPC機はGPU性能が高くない代わりにサーバー機よりもこの処理に対するCPU性能が高いため、GPUによる高速化効果の高いTruckとCPU処理に依存した処理の合計が同程度になったようである。デスクトップ機では3つの処理全体で、サーバー機の3つ処理全体の0.29倍の実行時間であった。3つの処理のうちGPUによる処理速度への依存が大きいTruckの実行時間は、同一のGPUを使用しているため同程度になっている。他のLicenseとTankの処理はデスクトップ機の方が、サーバー機の平均実行時間の0.26倍となっており、このシステムの処理へのCPU処理性能の差によってこの実行時間の差が生じていることがわかる。

サーバー機は24時間稼働に特化しているおり頑健性や耐環境性に優れ、厳しい環境条件下でも安定して動作する可能性が高い。CPU依存の高負荷な処理を最適化により負荷を軽減するか、処理自体を他の機器で行うことで、システム全体の負荷を軽減することが可能である。また、外部ネットワークと接続できない環境下でも建設現場の気象データ、機械の動作データ、作業員の位置データなどのデータをIoT機器およびセンサー類から収集して、データを一元管理して分析を行う用途での活用が考えられる。

表-2 エッジ AI システム測定箇所

処理	計測区間
Truck	トラックミキサーをYOLOで物体検出する時間
License	検出したナンバープレートの歪み補正とYOLOで文字認識する時間
Tank	Farneback法によるoptical flowのCPU計算

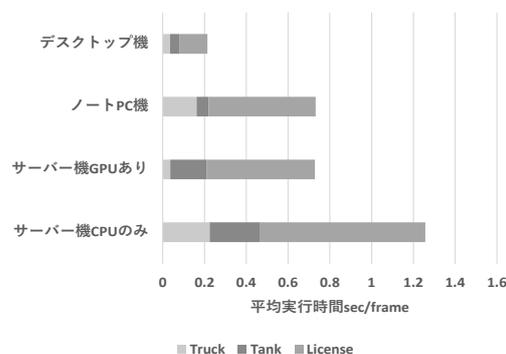


図-3 各ハードウェア実行速度の比較

3.2 エッジAI システムの結果と考察

(1) ナンバープレートの文字認識について

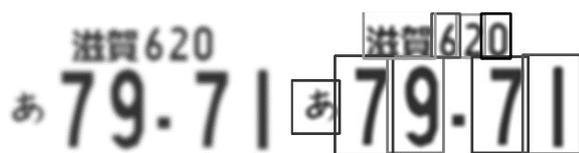


図-4 自動生成したナンバープレート画像と文字検出

図4は訓練データ量が不足しているナンバープレートの画像を補うために自動生成した画像に対し、ナンバープレートで出現する数字・漢字・ひらがなで転移学習したYOLOモデルで文字検出をした結果である。

図4に示したように、正面のナンバープレートには文字検出が成功しやすいが、タンクとナンバープレートを1画面で収めるために斜めからナンバープレートが撮影される。そのままでは文字認識精度が下がってしまうため、検出したナンバープレート画像の輪郭を検出して、台形補正や傾き補正を行い長方形になるようにした。この手法を使う場合にナンバープレートと、車体の色が同化してしまい輪郭が判別しづらい場合に補正に失敗する課題がある。また、台形補正をする場合に角度と距離によって、抽出できるナンバープレート画像の解像度が低くなってしまうため、カメラの撮影時の性能によって異なる認識の限界角度と距離をカメラ設置時に確認しやすくする必要がある。特に、漢字およびひらがな部分は文字がつぶれてしまい精度が悪化する原因になっていた。また、つぶれていない状態であっても似たひらがなと誤読するパターンも存在した。数字の箇所は大きな数字は正解しやすく、小さい数字はつぶれていない状態では読み取り精度が漢字とひらがなより高い。

(2) タンクの回転方向の判別について

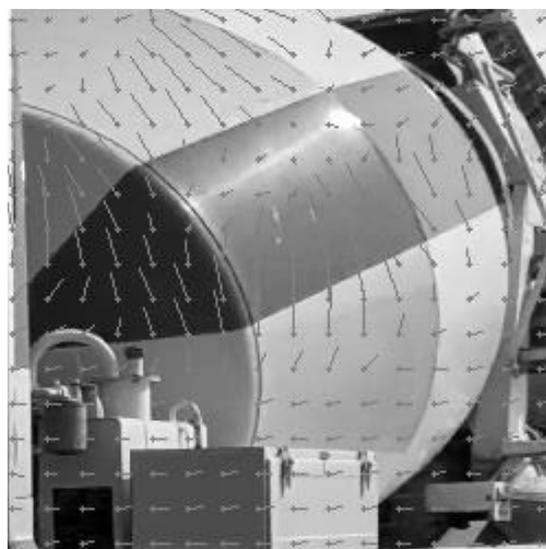


図-5 タンクの回転方向の検出

図5は、タンクの回転方向をoptical flowを計算し、検出したoptical flowのベクトルを、グリッド状に矢印で並べたものである。図5に示したように、ピクセルの動きがわかりやすい模様や、タンクのつなぎ目の動きに反応して回転方向が判別可能である。トラックミキサーはタンクの回転方向は後ろから見て時計回りのときに、コンクリートを排出する。それに対して、タンクの回転向きが反時計回りかまたは回転が停止しているときは、コンクリートの排出されない状態であることから、タンクの回転方向を判別することでコンクリート打設の開始と終了時刻の検出を可能にした。

4. まとめ

本研究では、中小建設業者の現場施工者を支援する目的で、通信が困難な環境でも使えるエッジコンピューティングと深層学習モデル(YOLOとRAFT)を用いたコンクリート打設の自動管理システムを開発し、その有用性を実証した。

自動管理システムは、ナンバープレートの自動読み取りとタンクの回転方向の検出を行い、これによって作業の効率化と省人化を図る。

実行速度の比較では、サーバー機のCPU性能が他の機器に比べて劣っていたが、24時間稼働に特化しているおり頑健性や耐環境性に優れ、厳しい環境条件下でも安定して動作するため、外部ネットワークと接続できない環境下でも建設現場の気象データ、機械の動作データ、作業員の位置データなどのデータをIoT機器およびセンサー類から収集して、データを一元管理して分析を行う用途での活用が考えられる。CPU依存の処理は、その他の高性能なCPUを持つ機器で行うことで、サーバー機の負荷を軽減する方針が有効であると判明した。

今後の課題としては、望遠カメラによる入力画像の高解像度化や複数カメラの連携の実証、さらなるデータ収集と分析によるシステムの精度向上、そして中小建設業者が容易に導入できるようなシステム設計の最適化が挙げられる。本研究が示したエッジAIシステムの有用性は、建設業界におけるDX推進の一翼を担うものと期待される。

参考文献

- 1) 建山知由・横山隆明：ICTを利用した建設施工の高度化と将来展望，計測と制御，55・6，pp. 477-482，2016
- 2) JosephRedmon・SantoshDivvala・RossGirshick・AliFarhadi：You Only Look Once: Unified, Real-Time Object Detection，CVPR，2016
- 3) Zachary Teed, Jia Deng：RAFT: Recurrent All-Pairs Field Transforms for Optical Flow，ECCV，2020